

大規模救急データを活用した機械学習による 細粒度救急需要予測モデルの構築と評価

金田 真輝[†] 陳 思楠[†] 中村 匡秀^{†,††} 佐伯 幸郎^{†††}

[†] 神戸大学 〒657-8501 神戸市灘区六甲台町 1-1

^{††} 理化学研究所・革新知能統合研究センター 〒103-0027 東京都中央区日本橋 1-4-1

^{†††} 高知工科大学 〒782-8502 高知県香美市土佐山田町宮ノ口 185

E-mail: [†]masaki-k@es4.eeddept.kobe-u.ac.jp, ^{††}chensinan@gold.kobe-u.ac.jp, ^{†††}masa-n@cmds.kobe-u.ac.jp,
^{††††}saiki.sachio@kochi-tech.ac.jp

あらまし 近年、日本は超高齢社会に直面しており、救急医療の逼迫、救急搬送件数の増加の問題は深刻である。本研究では将来救急需要の細粒度予測に着目し、救急隊の戦略的な配備や医療現場における規模の拡大縮小の指標の提供をすることを目的とする。手法としては各地の救急ビッグデータと人口予測、人口実績をもとに機械学習を行うことで細かな地域単位（小学校区）、数日先等の粒度で救急需要の予測する。作成した機械学習モデルは過去のデータを用いてその性能を評価し、さらには 2025～2050 年までの将来救急需要の予測を行った。予測の結果将来の救急需要における地域間の増加率の偏り、季節性による数日間の急上昇を予測することができ、救急リソースの最適配置や救急隊の編隊の指標を示すことができた。

キーワード 救急需要, 高齢化, 医療逼迫, データサイエンス, ビッグデータ, 機械学習

Construction and Evaluation of a Model for fine-grained Future Emergency Medical Services Demand Using EMS Big Data Based on Machine Learning

Maseki KANEDA[†], Sinan CHEN[†], Masahide NAKAMURA^{†,††}, and Sachio SAIKI^{†††}

[†] Kobe University Rokkodai-cho 1-1, Nada-ku, Kobe, Hyogo 657-8501 Japan

^{††} Riken AIP 1-4-1 Nihon-bashi, Chuo-ku, Tokyo 103-0027 Japan

^{†††} Kochi University of Technology, 185 Miyanokuchi, Tosayamada, Kami City, Kochi 782-8502, JAPAN

E-mail: [†]masaki-k@es4.eeddept.kobe-u.ac.jp, ^{††}chensinan@gold.kobe-u.ac.jp, ^{†††}masa-n@cmds.kobe-u.ac.jp,
^{††††}saiki.sachio@kochi-tech.ac.jp

Abstract Japan is facing challenges due to its super-aging society, including increasing strain on emergency medical services and a rise in emergency transport cases. This study aims to provide indicators for the strategic deployment of emergency teams and adjustments in medical facility capacity by focusing on fine-grained forecasting of future emergency demand. Using machine learning with emergency big data, population forecasts, and actual population data, the model predicts demand at local levels and for short-term periods (primary school district). Evaluated with historical data, the model forecasts emergency demand from 2025 to 2050, highlighting regional disparities and short-term spikes due to seasonal factors.

Key words Emergency Demand, Ageing, Medical Compulsions, Data Science, Big Data, Machine Learning

1. はじめに

近年 ICT システムや IoT 技術の急速な発展により、企業のみならず政府や自治体が多種多様なデータを取得・蓄積して施策や街づくりに役立てる動きが活発になってきている。こうした

様々なデータを利活用することで、より効率的で持続的な都市、スマートシティ [1] を目指すことは、今や世界的な潮流となっている。また、近年の日本各地における慢性的な少子高齢化の影響は多岐にわたっており、その中でも救急医療の逼迫、救急搬送数の増加は深刻な問題となっている。これに対し、総務省

は日本全国に向けて早急な対応を呼びかけている [2]。我々研究グループは神戸市消防局と共同研究をしており、救急出動に関するデータを ICT システムにより収集・記録している。その中でも本研究は、救急ビッグデータと人口推計データを活用し、機械学習を用いた救急需要予測モデルの構築を目指す。特に、細かい地域単位や短期的な期間（数日先）での需要変動を予測することを目的とする。提案手法は大きく 3 つのアプローチを経て将来救急需要予測モデルを構築、評価するものである。

学習データの抽出、作成

救急ビッグデータや人口動態データから、救急搬送件数や年齢、性別、地域などの属性を抽出し、機械学習モデルの学習データを作成する。さらに、救急搬送件数の移動平均とその差分を計算し、予測のための基礎データを整える。

予測モデルの構築

LightGBM を用いて救急需要予測モデルを構築する。このアルゴリズムは、決定木に基づく機械学習手法で、迅速かつ高精度な予測が可能であり、このモデルは、過去のデータを元に、将来の搬送件数を予測するために最適化される。

予測モデルの評価、検証

構築した予測モデルを評価するために、過去のデータを使用して予測精度の検証を行う。評価指標として平均二乗誤差 (MSE) や R2 スコアを用い、予測の精度を数値的に確認し、これにより、モデルの信頼性と実用性を確保する。

神戸市にて行った実験検証では、結果として提案した予測モデルが高精度で救急搬送件数を予測できることが確認できた。特に、移動平均に基づく予測では R2 スコアが非常に高く、誤差が小さいことが示された。また、移動平均差を用いた予測も、急激な需要変動を捉える点で有用であると評価した。

さらに、小学校区ごとの誤差率と 2025 年から 2050 年にかけての予測結果では、地域ごとに異なる増加率や季節性による需要の急増が確認され、救急リソースの最適配置や救急隊の編成に対して具体的な指標を提供できることが明らかになった。

2. 準備

2.1 高齢化による救急需要の増加

近年、日本全国において慢性的に高齢化率は上昇が続いている。[3] 高齢化率とは、総人口に占める 65 歳以上の者の割合のことを示しており、令和 5 年（2023 年）時点で高齢化率は 29.1 %、その後も上昇を続け、2060 年には約 2.5 人に 1 人が 65 歳以上、約 3.9 人に 1 人が 75 歳以上の超高齢社会が到来すると考えられている。[4]2023 年消防白書によると「令和 4 年中の救急自動車による救急出動件数は、722 万 9572 件であり、対前年比で増加した。令和 5 年に行った将来推計によると、高齢化の進展等により救急需要は今後増大する可能性が高いことが示されており、救急活動時間の延縮を防ぐとともに、これに伴う救急率の低下を防ぐための対策が必要である。」と記述されている。我々が生活している神戸市においても日本全国の都市同様に高齢化がみられ、それに伴う救急需要の増大、救急リソースの逼迫が問題視されている。

2.2 神戸消防局との共同研究

我々が共同研究を行っている神戸市消防局では、スマートシティを目指す取り組みの一環として、救急出動に関するデータを ICT システムにより収集・記録している。救急出動に関するデータには、各救急出動に対して、出動隊や車両のデータ、通報日時や現場駆け付け日時などの時刻データ、傷病者の年齢や性別などの搬送者属性に関するデータ、発生場所区分や屋内外といった空間に関するデータなどが記録されている。記録されているデータの一例を表に示す。なお、例示しているデータは仮のものであるため、一部のデータを省略・削除している。この救急出動に関する膨大なデータ（以降、**救急ビッグデータ**と呼ぶ）を分析・活用することで、これまで定量的な評価が困難であった、救急リソースの逼迫度合の定量化、救急需要を満たすための救急リソース配置の最適化など、救急事業の改善が実現可能である。また過去に救急ビッグデータを用いた救急需要の分析事例 [5] など挙げられ、実際に救急事業の改善を行うことができていた前例が存在する。

表 1 救急ビッグデータの内容例

	発生時間	傷病名	…	年齢	出動場所	傷病程度
1	2021-01-01 00:02:21	腎不全	…	57	兵庫区中道通	軽症
2	2022-01-01 00:02:51	肺炎	…	58	中央区相生町	軽症
3	2023-01-01 00:00:42	脳梗塞	…	74	垂水区高丸	中等症

2.3 機械学習・深層学習

機械学習 (Machine Learning) とは、大量のデータを読み込ませ、データ内の潜在的なパターンを学習させることで、未知のデータに対しても判断ができるためのルールを獲得することを可能にするデータ解析技術である。[6] 機械学習の種類は様々で教師あり学習、教師なし学習、強化学習などが存在する。一方で深層学習 (Deep Learning) とは、人間の神経細胞の仕組みを再現したニューラルネットワークを用いた機械学習の手法の 1 つであり、多層構造のニューラルネットワークを用いることが特徴である。[7] 深層学習では、ニューラルネットワークの隠れ層（中間層）を大幅に多層化しているので、自力で分析・抽出に必要な特徴を見つけ、精度の高いデータ処理を行うことが可能になる。昨今ではこれらの機械学習を用いて需要予測や不正検知、自動運転に至るまで様々な分野で活用がされており、私達の生活に大きな変化を与えている。

2.4 取り組む課題

章 2.1 で述べたように、近年日本では急速に高齢化が進んでおり、救急需要は増大、多様化を極めてきている。この現状に対処するため、救急医療現場では救急業務を取り巻く諸課題への早急な対応策が必須になってきている。しかし、具体的な救急動態や需要変化をとらえることは困難で、救急需要の増加や救急リソースの逼迫が深刻化していくにもかかわらず、大規模な救急隊の編隊や臨時救急隊の増編成が確固たる根拠な

しには実行することが難しい状態にある。

2.5 技術的なチャレンジ

機械学習を用いた需要予測は分析対象を長期間等の荒い粒度で行っていることが多く、数日先等の予測を高い精度で予測することは非常に困難であるとされている。また今回扱う救急需要予測については過去 10 年分程度しか実績データが存在しないことが一般的である。そのため、教師とするデータが足りず予測の精度が不十分であるという課題がある。また、単純に搬送件数を機械学習で予測するだけでは、全体としての搬送件数の特性しか把握できず、指数関数的に増加しつつある高齢者数や特定の地域での搬送率や年齢分布の特徴など、様々な要因が救急搬送件数に与える影響を考慮できない問題もある。

3. 提案手法

3.1 研究の目的

本研究の目的は、多様化し増大しつつある救急需要に備え、救急隊の戦略的な配備や医療施設における規模の拡大縮小の指標の提供をすることである。そのために、数日先等の細かな単位で機械学習を用いて、将来救急需要を予測、評価を行う。

3.2 提案手法の概要

本研究では救急需要予測の前事例を参考に、LightGBM [8] を用いた救急需要予測モデルの構築を行う。本研究にて提案する予測モデルとデータのアーキテクチャ、アプローチを以下に示す。

- A1：学習データの抽出、作成
- A2：予測モデルの構築
- A3：予測モデルの評価、検証

3.3 A1：学習データの抽出、作成

まず初めに概要図 1 の様に、機械学習の教師となる学習データの抽出、作成を行う。救急ビッグデータからは年数、性別（男女）、年代区分（子供 [18 歳未満]、成人 [18 歳以上 65 歳未満]、高齢者 [65 歳以上]）、行政区名、週数（元旦から第何週目という指標）ごとに救急搬送件数を集計しデータの抽出を行う。次に人口実績データからは先程抽出した属性ごとの人口を抽出し結合を行う。次に作成したデータに対して救急搬送件数の移動平均と移動平均との差を算出する。ここにおける移動平均とは、一定の範囲ごとの平均値をその範囲をずらしながら平均をとり、データを平滑化したものである。範囲はデータの地点の前後 12 週間で算出する。それぞれの属性や移動平均のパラメータの設定等は章 3.4 にて詳細に説明する。

3.4 A2：予測モデルの構築

予測モデルである機械学習モデルを構築するにあたり、様々な設定値の選定を行う。本研究では以下の 3 つの Phase をもって選定を行った。




図 1 学習データの抽出、作成

3.4.1 Phase1：目的変数の選定

数日後等の粒度が短期間の救急搬送件数を予測するにあたり、季節性や経年変化、その他の短い期間における影響を強く加味する必要がある。そこで移動平均 [9] と移動平均との差の二つの要素を目的変数に設定した。移動平均を採用することで、細かな変動を取り除いた粒度の荒い傾向を加味した予測ができ、また移動平均との差を採用することで粒度の細かい部分の予測ができるようになる。


3.4.2 Phase2：説明変数の選定

本研究では、以前に行った救急需要予測 [5] を参考に、6 つの説明変数（年数、性別、年代区分、小学校区、週数、人口数）を設定した。関連研究で気象や気温等の属性を説明変数としている事例が多くあるが、将来予測において根拠ある将来予測値を設定することが困難であるため、本研究では説明変数として設定していない。本研究では、地域別を表す指標としてよく用いられる行政区単位ではなく小学校区を用いている [10]。理由としては、地方自治体や戦略を打ち出す消防局において施策の講じる単位は行政区よりもさらに細粒度化された小学校区であることからこの小学校区という単位を用いている。

3.4.3 Phase3：予測モデルの選定

本研究では、近年適用事例が増えているアルゴリズムで、非線形モデルある LightGBM を用い救急需要予測を行った。LightGBM (Light Gradient Boosting Machine) は、Microsoft によって開発されたオープンソースの機械学習フレームワークで、特に勾配ブースティングアルゴリズムに基づいている [8]。図 2 のような決定木最適化アルゴリズムを持ち、高速な学習速

度と高い精度を実現している。



Leaf-wise tree growth

図 2 LightGBM の仕組み

3.5 A3：予測モデルの評価，検証

機械学習モデルを構築する際に，教師データの 1% を検証用データとして分け評価を行う．この際は平均二乗誤差 (MSE) と R^2 スコアで評価を行う．平均二乗誤差 (MSE) とは実際の値と予測された値の間の誤差を評価する指標で小さいほどモデルの予測精度が高いとみなされる，また R^2 スコアはモデルが実際のデータの分散をどれだけうまく説明できているかを示す指標であり，1 に近いほど，モデルはデータの変動をよく説明できているとみなされる．それぞれの計算式を以下に示す．またそれらに加え，教師データを用いて救急搬送件数を予測しそれらの誤差評価を行う．

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

4. 実験検証

4.1 実験概要

本研究では，日本が全国的に抱える救急需要の急増と同様の傾向がみられる兵庫県神戸市において実際に検証を行う．また，変化しつつある救急需要に備え，救急隊の戦略的な配備や地方における医療現場の規模拡大縮小の指標の提供を行う目的のために以下のように RQ (リサーチ・クエスチョン) を設定し，具体的に結論を出す．

- RQ1：数日 (週間程度) の粒度で精度を保った予測ができていますか？
- RQ2：救急リソースの戦略的な配備の指標になり得るのか？

4.1.1 利用した技術，データ

提案手法の実験検証には以下の技術を用いた．

- 開発言語：Python3
- 使用したライブラリやツール：pandas, sklearn, matplotlib, numpy, lightgbm, jupyter Notebook
- 利用したデータ：神戸市救急ビッグデータ [2013～2023 年]，神戸市将来人口推計データ [2023～2050 年] [11]，神戸人口推計実績 [12]

4.1.2 検証設定

- 移動平均の範囲は前後 6 週
- 目的変数は救急搬送件数における移動平均と移動平均の差の 2 値．説明変数は年数，性別，年代区分，行政区名，週数，人口数の 6 値．うち性別，年代区分，小学校区名，週数の 4 値はカテゴリカル変数に設定
- MinMaxScaler を使い，数値変数 (人口，年数) を [-1, 1] の範囲にスケーリング
- train_test_split を使い，データセットの 1% をテストデータとする

4.2 検証の結果

4.2.1 A1 の結果

章 3.3 で紹介した手法をもとに救急データと人口実績データから抽出，整形を行った．表 ?? には今回の実験検証にて使用した学習データの一部を示す．

表 2 学習データの一部

	年数	性別	年代区分	小学校区名	週数	人口数	搬送件数	移動平均	移動平均との差
0	2019	女	子供	ありの台小学校	1	532	1	8.307692	0.692308
1	2021	女	子供	ありの台小学校	1	508	0	0.296296	-0.296296
2	2020	女	子供	ありの台小学校	1	512	2	0.266667	1.733333
...	...	...	...	...	...	...	...	...	...
30885	2013	男	高齢者	こうべ小学校	52	1862	13	13.551724	-0.551724
30886	2022	男	高齢者	こうべ小学校	52	1944	21	13.571429	7.428571
30887	2023	男	高齢者	こうべ小学校	52	2002	17	13.740741	3.259259

4.2.2 A2 の結果

章 3.4 に従い，LightGBM による予測モデル構築を行った．以下に目的変数である移動平均と移動平均との差の評価を示す．図 3 はモデル構築時の検証の結果を表している．結果を見るに，移動平均に関しては R^2 スコアが約 95 とかなり高く出ており，過学習の可能性が挙げられるが，粒度の荒い予測を行っている要素であるため問題がないものとする．値の平均値に対して MSE が 0.17 と低く出ており，値が 20 程度のスケールにおいてこれも精度がかなり高く出ている．一方で移動平均の差の方は一見 MSE:1.65 と R^2 スコア:0.261 と精度が悪く見えるが，これは搬送件数として移動平均と足し合わせて予測値として際に与える影響はごくわずかと小さく，また結果の波形として突出点等をとらえることができていたため有用であると判断した．






図 3 モデル構築検証結果

章 3.5 に従い、2013～2023 年のデータを使用して予測検証を行った。図 4 は、実測値との評価を行った移動平均の結果とそれらの誤差率のグラフである。図 5 は図 4 と同様の移動平均との差の結果である。二つの指標ともに予測値と実測値で大きな乖離が生じている週がある。2018 年の夏の異常気象による熱中症の搬送件数の急増や、2020 年の新型コロナウイルスによる外出規制で外的要因の救急搬送の急減等の影響を受け大きな乖離が生じていた。



最後に予測結果全体として RQ に対する回答を行う。RQ1：数日（週間程度）の粒度で精度を保った予測ができていますか？ A1：予測モデル評価により、低い誤差率を保った予測ができています。RQ2：救急リソースの戦略的な配備の指標になり得るのか？ A2：週単位の予測を高い精度で実現できており、閾値を定めることができればどのタイミングで医療逼迫が起こるか判断することができるため、臨時救急隊を編成等の対策を取るこ

[illegible]

図 6 小学校区ごとの誤差率




図 7 2013-2050 の年単位救急搬送件数予測と実測値との比較

5.1 全体の結果

- 212 -

5.2 提案手法の限界

本研究の提案手法にはいくつかの限界が存在する。第一に、過去のデータのみに基づいた予測であるため、予測に用いたデータセットの質や範囲に依存する部分が大きいたことが挙げられる。特に、使用したデータは過去 10 年程度のものであり、予測モデルの精度向上のためにはより長期間のデータが必要となる可能性がある。また、異常気象やパンデミック（例えば、2020 年の新型コロナウイルスの影響）のような外的要因による予測値の急激な変動については、モデルが完全に適応しきれていない部分が確認できた。これにより、特定の時期や状況において予測誤差が大きくなることが課題であると考えられる。さらに、気象や社会的要因を説明変数として含めていないため、予測精度をさらに高めるにはこれらの要素の追加も検討が必要であるとも考えている。

これらの限界を踏まえ、今後は異常値に対応したモデルの改善や、説明変数の多様化を図ることで、より精度の高い予測が可能になると考えられる。

6. ま と め

本研究では、日本の超高齢社会における救急医療の逼迫に対応するため、救急ビッグデータと人口推計を基にした機械学習モデルを構築し、将来の救急搬送需要の予測を行った。さらにこの提案手法が具体的にどのように実行され、また正確に指標の提供となるような結果が得られるのか確認した。これらを活用した救急医療の現状把握や効率化、さらには新型コロナウイルス COVID-19 に対する適切な対策が期待される。このような状況を鑑み、さらなる救急需要予測プロセスの厳密化、正確化に加え一般化できるような環境にしていくことが望まれる。

謝 辞 本研究の一部は JSPS 科研費 JP20H05706, JP22H03699, JP22K19653, JP23H03401, JP23H03694, JP23K17006 の助成を受けて行われている。本研究は神戸市消防局との共同研究の一環で行われている。

文 献

- [1] M. Deakin and H. Al Waer, “From intelligent to smart cities,” *Intelligent Buildings International*, vol.3, no.3, pp.140–152, 2011.
- [2] “総務省 | 報道資料 | 「令和 4 年度 救急業務のあり方に関する検討会」の発足及び開催,” https://www.soumu.go.jp/menu_news/s-news/01shoubo01_02000591.html, July 2022. (Accessed on 24 January 2023).
- [3] “日本全国において慢性的に高齢化率,” https://www8.cao.go.jp/kourei/whitepaper/w-2020/html/zenbun/s1_1_1.html. (Accessed on 24 January 2024).
- [4] “高齢化率,” <https://www.stat.go.jp/data/topics/pdf/topics138.pdf>. (Accessed on 24 January 2024).
- [5] 金田真輝, 陳思楠, 中村匡秀, 佐伯幸郎, “大規模救急データと年代別人口推計データに基づく長期的救急需要予測手法の提案,” 電子情報通信学会技術研究報告; 信学技報, pp.●●●●, 2023.
- [6] “機械学習とは? 機械学習の仕組みとディープラーニングとの違いを分かりやすく解説 | gsl コラム | ntt データ グローバルソリューションズ,” <https://www.nttdata-gsl.co.jp>

</related/column/what-is-machine-learning.html>. (Accessed on 10/07/2024).

- [7] “深層学習とは? 意味・定義 | it 用語集 | docomo business watch | ドコモビジネス | ntt コミュニケーションズ 法人のお客さま,” <https://www.ntt.com/bizon/glossary/j-s/deep-learning.html>. (Accessed on 10/07/2024).
- [8] “Lightgbm | 用語解説 | 野村総合研究所 (nri),” https://www.nri.com/jp/knowledge/glossary/1st/alphabet/light_gbm. (Accessed on 10/09/2024).
- [9] “32-3. 時系列データと移動平均 | 統計学の時間 | 統計web,” https://bellcurve.jp/statistics/course/12933.html?srsId=AfmB0opIFj2grM0qxPv0kzAg8XWxRfbobQpyu6M_KilJt0tkDa1hb4BQ. (Accessed on 10/09/2024).
- [10] “国土数値情報 | 小学校区データ,” <https://nlftp.mlit.go.jp/ksj/jpgis/datalist/KsjTmplt-A27.html>. (Accessed on 31 January 2024).
- [11] “神戸市: 人口統計,” <https://www.city.kobe.lg.jp/a47946/shise/toke/toukei/jinkou/index.html>. (Accessed on 10/09/2024).
- [12] “政府統計の総合窓口,” <https://www.e-stat.go.jp/>. (Accessed on 31 January 2024).